下载APP

01｜Spark：从“大数据的Hello World”开始

2021-09-06 吴磊

《零基础入门Spark》

课程介绍 >

讲述：吴磊

时长 19:59　大小 18.31M

你好，我是吴磊。

从这节课开始，我们先来学习 Spark 的“基础知识”模块，对 Spark 的概念和核心原理先做一个整体的了解。我并不会从 RDD、DAG 这些基本概念给你讲起。坦白地说，这些抽象的概念枯燥而又乏味，对于刚开始接触 Spark 的你来说，很难学进去。因此，我们不妨反其道而行之，先从实战入手，用一个小例子来直观地认识 Spark，看看 Spark 都能做些什么。

这就好比我们学习一门新的编程语言，往往都是从“Hello World”开始。我还记得，[illegible]学编程那会，屏幕上打印出的“Hello World”，足足让我兴奋了一整天，让我莫名地有一种“I can change the world”的冲动。

今天这一讲，我们就从“大数据的 Hello World”开始，去学习怎么在 Spark 之上做应用开发。不过，“大数据的 Hello World”并不是把字符串打印到屏幕上这么简单，而是要先对文件中的单词做统计计数，然后再打印出频次最高的 5 个单词，江湖人称“Word Count”。

之所以会选择 Word Count，作为我们迈入 Spark 门槛的第一个项目，主要有两个原因，一是 Word Count 场景比较简单、容易理解；二是 Word Count 麻雀虽小，但五脏俱全，一个小小的 Word Count，就能够牵引出 Spark 许多的核心原理，帮助我们快速入门。

好啦，话不多说，下面我们正式开启 Word Count 之旅。

准备工作

巧妇难为无米之炊，要做 Word Count，我们得先把源文件准备好。

咱们做 Word Count 的初衷是学习 Spark，因此源文件的内容无足轻重。这里我提取了 Wikipedia 中对 Spark 的介绍来做我们的源文件。我把它保存到了与课程配套的 Github 项目中，并把它命名为“wikiOfSpark.txt”。你可以从这里下载它。

为了跑通 Word Count 实例，我们还需要在本地（Local）部署 Spark 运行环境。这里的“本地”，指的是你手头能够获取到的任何计算资源，比如服务器、台式机，或是笔记本电脑。

在本地部署 Spark 运行环境非常简单，即便你从来没有和 Spark 打过交道，也不必担心。**只需要下面这 3 个步骤，我们就可以完成 Spark 的本地部署**：

1. **下载安装包：**从 Spark 官网下载安装包，选择最新的预编译版本即可；
2. **解压：**解压 Spark 安装包到任意本地目录；
3. **配置：**将“${解压目录}/bin”配置到 PATH 环境变量。

接下来，我们确认一下 Spark 是否部署成功。打开命令行终端，敲入“spark-shell --version”命令，如果该命令能成功地打印出 Spark 版本号，就表示我们大功告成了，就像这样：

```
(base) wulei@wulei-mac ~ % spark-shell --version
WARNING: An illegal reflective access operation has occurred
WARNING: Illegal reflective access by org.apache.spark.unsafe.P
ars/spark-unsafe_2.12-3.0.1.jar) to constructor java.nio.Direct
WARNING: Please consider reporting this to the maintainers of o
WARNING: Use --illegal-access=warn to enable warnings of furthe
WARNING: All illegal access operations will be denied in a futu
Welcome to
      ____              __
     / __/__  ___ _____/ /__
    _\ \/ _ \/ _ `/ __/  '_/
   /___/ .__/\_,_/_/ /_/\_\   version 3.0.1
      /_/

Using Scala version 2.12.10, OpenJDK 64-Bit Server VM, 15.0.1
Branch HEAD
Compiled by user ubuntu on 2020-08-28T07:36:48Z
Revision 2b147c4cd50da32fe2b4167f97c8142102a0510d
Url https://gitbox.apache.org/repos/asf/spark.git
Type --help for more information.
```

验证Spark本地部署成功

在后续的实战中，我们会用 spark-shell 来演示 Word Count 的执行过程。spark-shell 是提交 Spark 作业众多方式中的一种，我们在后续的课程中还会展开介绍，这里你不妨暂时把它当做是 Spark 中的 Linux shell。spark-shell 提供交互式的运行环境（REPL，Read-Evaluate-Print-Loop），以“所见即所得”的方式，让开发者在提交源代码之后，就可以迅速地获取执行结果。

不过，需要注意的是，spark-shell 的运行时，依赖于 Java 和 Scala 语言环境。因此，为了保证 spark-shell 的成功启动，你需要在本地预装 Java 与 Scala。好消息是，关于 Java 与 Scala 的安装，网上的资料非常丰富，你可以参考那些资料来进行安装，咱们在本讲就不再赘述 Java 与 Scala 的安装步骤啦。

梳理Word Count 的计算步骤

做了一番准备之后，接下来，我们就可以开始写代码了。不过，在“下手”之前，咱们不妨一起梳理下 Word Count 的计算步骤，先做到心中有数，然后再垒代码也不迟。

之前我们提到，Word Count 的初衷是对文件中的单词做统计计数，打印出频次最高的 5 个词汇。那么 Word Count 的第一步就很明显了，当然是得读取文件的内容，不然咱们统计什么呢？

我们准备好的文件是 wikiOfSpark.txt，它以纯文本的方式记录了关于 Spark 的简单介绍，我摘取了其中的部分内容给你看一下：

```
(base) wulei@wulei-mac 01_让我们从HelloWorld开始 % head wikiOfSpark.txt
Apache Spark
From Wikipedia, the free encyclopedia
Jump to navigationJump to search
Apache Spark
Spark Logo
Original author(s)      Matei Zaharia
Developer(s)    Apache Spark
Initial release May 26, 2014; 6 years ago
Stable release
3.1.1 / March 2, 2021; 2 months ago
```

wikiOfSpark.txt内容摘要

我们知道，文件的读取往往是以行（Line）为单位的。不难发现，wikiOfSpark.txt 的每一行都包含多个单词。

我们要是以“单词”做为粒度做计数，就需要对每一行的文本做分词。分词过后，文件中的每一句话，都被打散成了一个个单词。这样一来，我们就可以按照单词做分组计数了。这就是 Word Count 的计算过程，主要包含如下 3 个步骤：

1. **读取内容**：调用 Spark 文件读取 API，加载 wikiOfSpark.txt 文件内容；
2. **分词**：以行（Line）为单位，把句子打散为单词；
3. **分组计数**：按照单词做分组计数。

明确了计算步骤后，接下来我们就可以调用 Spark 开发 API，对这些步骤进行代码实现，从而完成 Word Count 的应用开发。

众所周知，Spark 支持种类丰富的开发语言，如 Scala、Java、Python，等等。你可以结合个人偏好和开发习惯，任意选择其中的一种进行开发。尽管不同语言的开发 API 在语法上有着细微的差异，但不论是功能方面、还是性能方面，Spark 对于每一种语言的支持都是一致的。换句话说，同样是 Word Count，你用 Scala 实现也行，用 Python 实现也可以，两份代码的执行结果是一致的。不仅如此，在同样的计算资源下，两份代码的执行效率也是一样的。

因此，就 Word Count 这个示例来说，开发语言不是重点，我们不妨选择 Scala。你可能会说：“我本来对 Spark 就不熟，更没有接触过 Scala，一上来就用 Scala 演示 Spark 应用代码，理解起来会不会很困难？”

其实大可不必担心，Scala 语法比较简洁，Word Count 的 Scala 实现不超过 10 行代码。再者，对于 Word Count 中的每一行 Scala 代码，我会带着你手把手、逐行地进行讲解和分析。我相信，跟着我过完一遍代码之后，你能很快地把它“翻译”成你熟悉的语言，比如 Java 或 Python。另外，Spark 源码中的绝大多数，都是由 Scala 实现的，接触并了解一些 Scala 的基本语法，有利于你后续阅读、学习 Spark 源代码。

Word Count 代码实现

选定了语言，接下来，我们就按照读取内容、分词、分组计数这三步来看看 Word Count 具体怎么实现。

第一步，读取内容

首先，我们调用 SparkContext 的 textFile 方法，读取源文件，也就是 wikiOfSpark.txt，代码如下表所示：

复制代码

```
import org.apache.spark.rdd.RDD

val rootPath: String = _
val file: String = s"${rootPath}/wikiOfSpark.txt"

// 读取文件内容
val lineRDD: RDD[String] = spark.sparkContext.textFile(file)
```

在这段代码中，你可能会发现 3 个新概念，分别是 spark、sparkContext 和 RDD。

其中，spark 和 sparkContext 分别是两种不同的开发入口实例：

> spark 是开发入口 SparkSession 实例（Instance），SparkSession 在 spark-shell 中会由系统自动创建；
>
> sparkContext 是开发入口 SparkContext 实例。

在 Spark 版本演进的过程中，从 2.0 版本开始，SparkSession 取代了 SparkContext，成为统一的开发入口。换句话说，要开发 Spark 应用，你必须先创建 SparkSession。关于 SparkSession 和 SparkContext，我会在后续的课程做更详细的介绍，这里你只要记住它们是必需的开发入口就可以了。

我们再来看看 RDD，RDD 的全称是 Resilient Distributed Dataset，意思是“弹性分布式数据集”。RDD 是 Spark 对于分布式数据的统一抽象，它定义了一系列分布式数据的基本属性与处理方法。关于 RDD 的定义、内涵与作用，我们留到下一讲再去展开。

在这里，你不妨先简单地把 RDD 理解成“数组”，比如代码中的 lineRDD 变量，它的类型是 RDD[String]，你可以暂时把它当成元素类型是 String 的数组，数组的每个元素都是文件中的一行字符串。

获取到文件内容之后，下一步我们就要做分词了。

第二步，分词

“分词”就是把“数组”的行元素打散为单词。要实现这一点，我们可以调用 RDD 的 flatMap 方法来完成。flatMap 操作在逻辑上可以分成两个步骤：**映射**和**展平**。

这两个步骤是什么意思呢？我们还是结合 Word Count 的例子来看：

复制代码

```
// 以行为单位做分词
val wordRDD: RDD[String] = lineRDD.flatMap(line => line.split(" "))
```

要把 lineRDD 的行元素转换为单词，我们得先用分隔符对每个行元素进行分割（Split），咱们这里的分隔符是空格。

分割之后，每个行元素就都变成了单词数组，元素类型也从 String 变成了 Array[String]，像这样以元素为单位进行转换的操作，统一称作“**映射**”。

映射过后，RDD 类型由原来的 RDD[String]变为 RDD[Array[String]]。如果把 RDD[String]看成是“数组”的话，那么 RDD[Array[String]]就是一个“二维数组”，它的每一个元素都是单词。

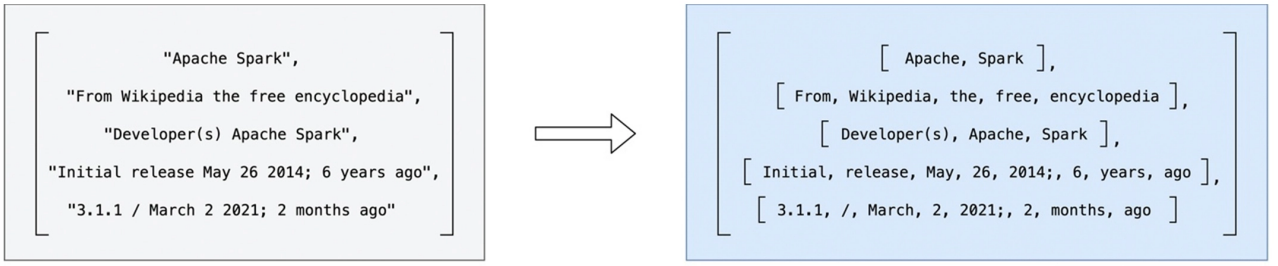

一维数组 RDD[String]　　二维数组 RDD[Array[String]]

极客时间

以行为单位做分词

为了后续对单词做分组，我们还需要对这个“二维数组”做**展平**，也就是去掉内层的嵌套结构，把“二维数组”还原成“一维数组”，如下图所示。

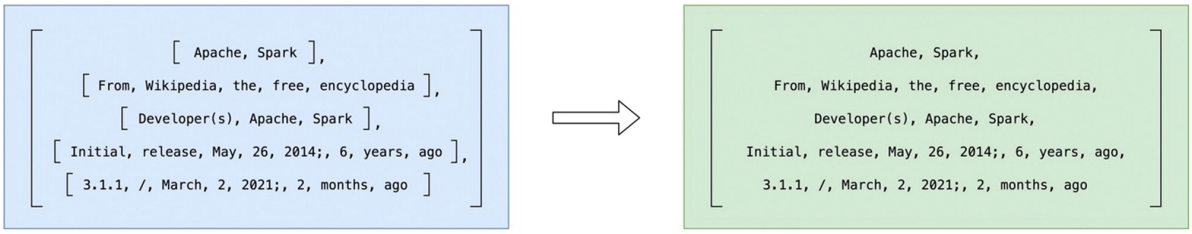

二维数组 RDD[Array[String]]　　一维数组 RDD[String]

极客时间

分词后做展平

就这样，在 flatMap 算子的作用下，原来以行为元素的 lineRDD，转换成了以单词为元素的 wordRDD。

不过，值得注意的是，我们用“空格”去分割句子，有可能会产生空字符串。所以，在完成“映射”和“展平”之后，对于这样的“单词”，我们要把其中的空字符串都过滤掉，这里我们调用 RDD 的 filter 方法来过滤：

复制代码

```
// 过滤掉空字符串
val cleanWordRDD: RDD[String] = wordRDD.filter(word => !word.equals(""))
```

这样一来，我们在分词阶段就得到了过滤掉空字符串之后的单词“数组”，类型是 RDD[String]。接下来，我们就可以准备做分组计数了。

第三步，分组计数

在 RDD 的开发框架下，聚合类操作，如计数、求和、求均值，需要依赖**键值对**（Key Value Pair）类型的数据元素，也就是（Key，Value）形式的“数组”元素。

因此，在调用聚合算子做分组计数之前，我们要先把 RDD 元素转换为（Key，Value）的形式，也就是把 RDD[String]映射成 RDD[(String, Int)]。

其中，我们统一把所有的 Value 置为 1。这样一来，对于同一个的单词，在后续的计数运算中，我们只要对 Value 做累加即可，就像这样：

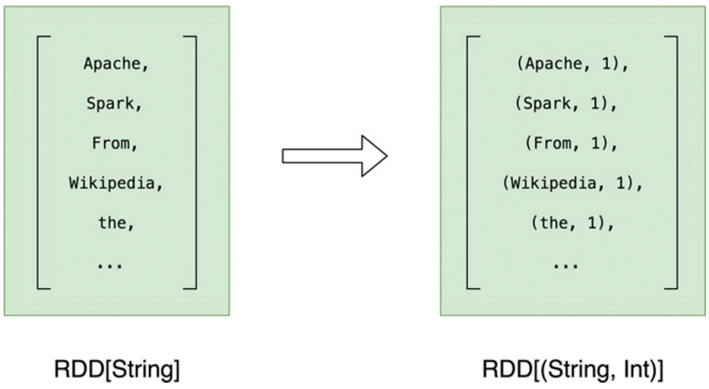

把元素转换为（Key，Value）形式

下面是对应的代码：

```
// 把RDD元素转换为（Key，Value）的形式
val kvRDD: RDD[(String, Int)] = cleanWordRDD.map(word => (word, 1))
```

这样一来，RDD 就由原来存储 String 元素的 cleanWordRDD，转换为了存储（String，Int）的 kvRDD。

完成了形式的转换之后，我们就该正式做分组计数了。分组计数其实是两个步骤，也就是先“分组”，再“计数”。下面，我们使用聚合算子 reduceByKey 来同时完成分组和计数这两个操作。

对于 kvRDD 这个键值对“数组”，reduceByKey 先是按照 Key（也就是单词）来做分组，分组之后，每个单词都有一个与之对应的 Value 列表。然后根据用户提供的聚合函数，对同一个 Key 的所有 Value 做 reduce 运算。

这里的 reduce，你可以理解成是一种计算步骤或是一种计算方法。当我们给定聚合函数后，它会用折叠的方式，把包含多个元素的列表转换为单个元素值，从而统计出不同元素的数量。

在 Word Count 的示例中，我们调用 reduceByKey 实现分组计算的代码如下：

复制代码

```
// 按照单词做分组计数
val wordCounts: RDD[(String, Int)] = kvRDD.reduceByKey((x, y) => x + y)
```

reduceByKey 分组聚合

可以看到，我们传递给 reduceByKey 算子的聚合函数是 (x, y) => x + y，也就是累加函数。因此，在每个单词分组之后，reduce 会使用累加函数，依次折叠计算 Value 列表中的所有元素，最终把元素列表转换为单词的频次。对于任意一个单词来说，reduce 的计算过程都是一样的，如下图所示。

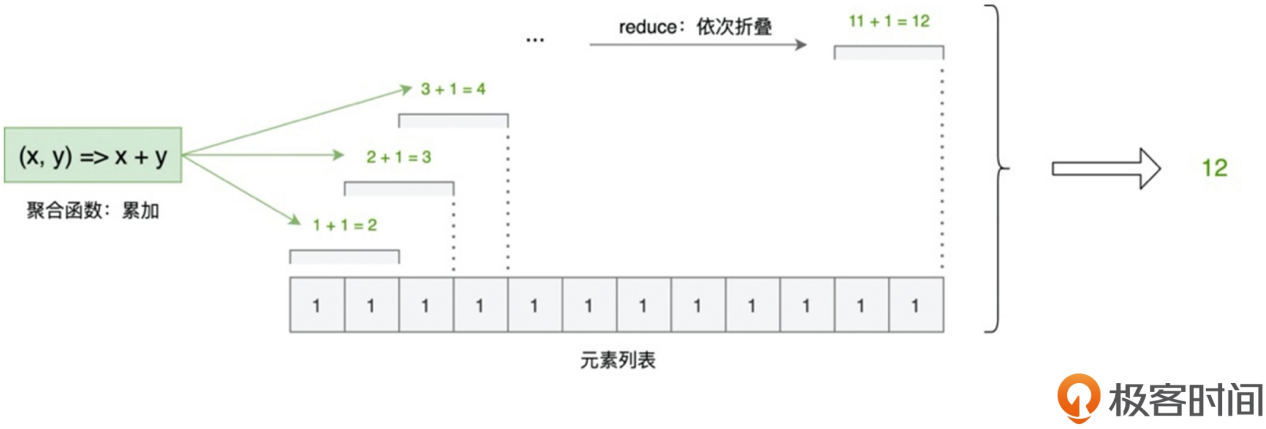

reduce操作示意图

reduceByKey 完成计算之后，我们得到的依然是类型为 RDD[(String, Int)]的 RDD。不过，与 kvRDD 不同，wordCounts 元素的 Value 值，记录的是每个单词的统计词频。到此为止，我们就完成了 Word Count 主逻辑的开发与实现。

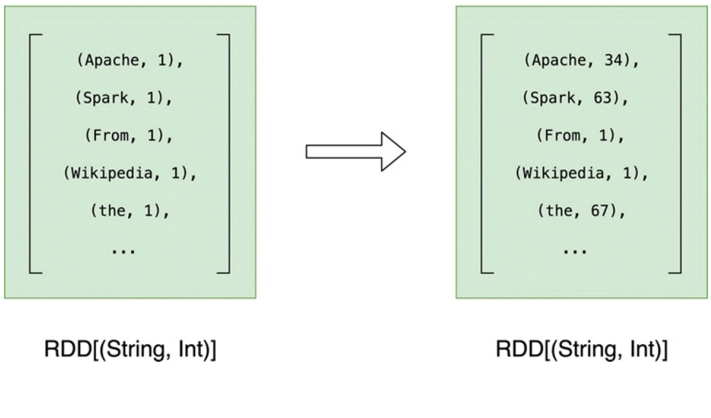

reduceByKey转换示意图

在程序的最后，我们还要把 wordCounts 按照词频做排序，并把词频最高的 5 个单词打印到屏幕上，代码如下所示。

```
// 打印词频最高的5个词汇
wordCounts.map{case (k, v) => (v, k)}.sortByKey(false).take(5)
```

按照词频排序并打印

代码执行

应用开发完成之后，我们就可以把代码丢进已经准备好的本地 Spark 部署环境里啦。首先，我们打开命令行终端（Terminal），敲入“spark-shell”，打开交互式运行环境，如下图所示。

```
(base) wulei@wulei-mac ~ % spark-shell
WARNING: An illegal reflective access operation has occurred
WARNING: Illegal reflective access by org.apache.spark.unsafe.Platform (file:/Users/wulei/Dow
ectByteBuffer(long,int)
WARNING: Please consider reporting this to the maintainers of org.apache.spark.unsafe.Platfor
WARNING: Use --illegal-access=warn to enable warnings of further illegal reflective access op
WARNING: All illegal access operations will be denied in a future release
21/06/08 16:47:57 WARN NativeCodeLoader: Unable to load native-hadoop library for your platfo
Using Spark's default log4j profile: org/apache/spark/log4j-defaults.properties
Setting default log level to "WARN".
To adjust logging level use sc.setLogLevel(newLevel). For SparkR, use setLogLevel(newLevel).
Spark context Web UI available at http://172.24.48.157:4040
Spark context available as 'sc' (master = local[*], app id = local-1623142081099).
Spark session available as 'spark'.
Welcome to
      ____              __
     / __/__  ___ _____/ /__
    _\ \/ _ \/ _ `/ __/  '_/
   /___/ .__/\_,_/_/ /_/\_\   version 3.0.1
      /_/

Using Scala version 2.12.10 (OpenJDK 64-Bit Server VM, Java 15.0.1)
Type in expressions to have them evaluated.
Type :help for more information.

scala>
```

spark-shell启动界面

然后，把我们开发好的代码，依次敲入 spark-shell。为了方便你操作，我把完整的代码实现整理到了如下面了：

复制代码

```
import org.apache.spark.rdd.RDD

val rootPath: String = _
val file: String = s"${rootPath}/wikiOfSpark.txt"

// 读取文件内容
val lineRDD: RDD[String] = spark.sparkContext.textFile(file)

// 以行为单位做分词
val wordRDD: RDD[String] = lineRDD.flatMap(line => line.split(" "))
val cleanWordRDD: RDD[String] = wordRDD.filter(word => !word.equals(""))

// 把RDD元素转换为（Key，Value）的形式
val kvRDD: RDD[(String, Int)] = cleanWordRDD.map(word => (word, 1))
// 按照单词做分组计数
val wordCounts: RDD[(String, Int)] = kvRDD.reduceByKey((x, y) => x + y)

// 打印词频最高的5个词汇
wordCounts.map{case (k, v) => (v, k)}.sortByKey(false).take(5)
```

我们把上面的代码依次敲入到 spark-shell 之后，spark-shell 最终会把词频最高的 5 个单词打印到屏幕上：

```
scala> wordCounts.map{case (k, v) => (v, k)}.sortByKey(false).take(5)
res26: Array[(Int, String)] = Array((67,the), (63,Spark), (54,a), (51,and), (50,of))
```

打印词频最高的5个词汇

在 Wikipedia 的 Spark 介绍文本中，词频最高的单词分别是 the、Spark、a、and 和 of，除了“Spark”之外，其他 4 个单词都是常用的停用词（Stop Word），因此它们几个高居榜首也就不足为怪了。

好啦，到此为止，我们在 Spark 之上，完成了“大数据领域 Hello World”的开发与实现，恭喜你跨入大数据开发的大门！

重点回顾

今天这一讲，我们围绕着 Word Count，初步探索并体验了 Spark 应用开发。你首先需要掌握的是 Spark 的本地部署，从而可以通过 spark-shell 来迅速熟悉 Spark，获得对 Spark 的“第一印象”。要在本地部署 Spark，你需要遵循 3 个步骤：

从Spark 官网下载安装包，选择最新的预编译版本即可；

解压 Spark 安装包到任意本地目录；

将“${解压目录}/bin”配置到 PATH 环境变量。

然后，我们一起分析并实现了入门 Spark 的第一个应用程序：Word Count。在我们的例子中，Word Count 要完成的计算任务，是先对文件中的单词做统计计数，然后再打印出频次最高的 5 个单词。它的实现过程分为 3 个步骤：

读取内容：调用 Spark 文件读取 API，加载 wikiOfSpark.txt 文件内容；

分词：以行（Line）为单位，把句子打散为单词；

分组计数：按照单词做分组计数。

也许你对 RDD API 还不熟悉，甚至从未接触过 Scala，不过没关系，完成了这次“大数据的 Hello World”开发之旅，你就已经踏上了新的征程。在接下来的课程里，让我们携手

并肩，像探索新大陆一样，一层一层地剥开 Spark 的神秘面纱，加油！

每课一练

在 Word Count 的代码实现中，我们用到了多种多样的 RDD 算子，如 map、filter、flatMap 和 reduceByKey，除了这些算子以外，你知道还有哪些常用的 RDD 算子吗？（提示，可以结合官网去查找）。

另外，你能说说，以上这些算子都有哪些共性或是共同点吗？

欢迎你把答案分享到评论区，我在评论区等你。

如果这一讲对你有帮助，也欢迎你分享给自己的朋友，我们下一讲再见！

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 0 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 开篇词 | 入门Spark，你需要学会“三步走”

精选留言 (1)

写留言

Stéphane 胡
2021-09-06

您好老师，请问一下多久会更新一讲呢？

展开

作者回复: 讲道理是周一、周三、周五各更一篇，不过今天上线我理解是预售，所以这周三、周五暂不更新。从下周开始，每周一、周三、周五各更一篇哈~